

VŠB – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra informatiky

Segmentace obrazu s využitím měření vzdálenosti

Distance-based image segmentation

Zadání bakalářské práce

Student:

Jakub Ondra

Studijní program:

B2647 Informační a komunikační technologie

Studijní obor:

2612R025 Informatika a výpočetní technika

Téma:

Segmentace obrazu s využitím měření vzdálenosti
Distance-based Image Segmentation

Jazyk vypracování:

čeština

Zásady pro vypracování:

Segmentace obrazu je technika počítačového vidění, která slouží k rozdělení obrazu do dílčích částí. Tyto části pak mohou být dále analyzovány. Jednou z možností segmentace obrazu je segmentace založená na měření vzdálenosti mezi jednotlivými body obrazu. Na základě změřené vzdálenosti pak lze určit, zda dané body patří do stejného segmentu. Cílem této práce je naimplementovat segmentační metodu založenou na měření vzdálenosti, vyzkoušet různé typy vzdáleností a porovnat jejich výsledky.

Ve své práci proveďte:

1. Popište metody segmentace obrazu s využitím měření vzdáleností.
2. Naimplementujte segmentační metodu v jazyce C/C++ nebo Python.
3. Otestujte metodu na vybraných obrazech, vyzkoušejte různé typy vzdáleností.
4. Zhodnoťte a porovnejte dosažené výsledky.

Seznam doporučené odborné literatury:


- [1] Toivanen, P.J.: New geodesic distance transforms for gray-scale images. Pattern Recogn. Lett. 17(5), 437-450 (May 1996)
- [2] Hajdu, A., Kormos, J., Nagy, B., Zrg, Z.: Choosing appropriate distance measurement in digital image segmentation. Annales Univ. Sci. Budapest. Sect. Comp 24, 193-208 (2004)
- [3] Criminisi, A., Sharp, T., Blake, A.: Geos: Geodesic image segmentation. In: Proc. European Conference on Computer Vision (ECCV). Lecture Notes in Computer Science, vol. 5302, pp. 99-112. Springer (2008)

Formální náležitosti a rozsah bakalářské práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.


Vedoucí bakalářské práce: **Ing. Michael Holuša**

Datum zadání: 01.09.2016

Datum odevzdání: 30.04.2018


doc. Ing. Jan Platoš, Ph.D.
vedoucí katedry




prof. Ing. Pavel Brandštetter, CSc.
děkan fakulty

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

V Ostravě 30. dubna 2018



.....

Rád bych na tomto místě poděkoval všem, kteří mi s prací pomohli, především svému vedoucímu za trpělivost a velmi užitečné rady.

Abstrakt

Segmentace obrazu je technika počítačového vidění, která slouží k rozdělení obrazu do dílčích částí. Tyto části pak mohou být dále analyzovány. Jednou z možností segmentace obrazu je segmentace založená na měření vzdálenosti mezi jednotlivými body obrazu. Na základě změřené vzdálenosti pak lze určit, zda dané body patří do stejného segmentu. Cílem této práce je naimplementovat segmentační metodu založenou na měření vzdálenosti, vyzkoušet různé typy vzdáleností a porovnat jejich výsledky.

Klíčová slova: segmentace obrazu podle vzdálenosti, minkowského vzdálenost, manhattanská vzdálenost, eukleidovská vzdálenost, geodetická vzdálenost, max-arc vzdálenost

Abstract

Image segmentation is a computer vision technique that serves to divide an image into sub-parts. These parts can then be further analyzed. One of the possibilities of image segmentation is segmentation based on the measurement of distance between individual pixels. Based on the measured distance, it is possible to determine whether the pixels belong to the same segment. The aim of this thesis is to implement a segmentation method based on distance measuring, to test different types of distances and to compare their results.

Key Words: distance-based image segmentation, minkowski distance, manhattan distance, euclidean distance, geodesic distance, max-arc distance

Obsah

Seznam obrázků	7
Seznam tabulek	8
Seznam výpisů zdrojového kódu	9
1 Úvod	10
2 Segmentace obrazu	11
2.1 Statické metody	11
2.2 Metody založené na detekci hran	12
2.3 Oblastně orientované metody	13
2.4 Segmentace založená na měření vzdálenosti	14
2.5 Znalostní metody	14
3 Metriky pro segmentaci využívající měření vzdálenosti	15
3.1 Minkowského vzdálenost	15
3.2 Čebyševova vzdálenost	16
3.3 Geodetická vzdálenost	17
3.4 Max-arc vzdálenost	18
4 Implementace	19
4.1 Načtení obrazu	19
4.2 Předzpracování obrazu	19
4.3 Převedení obrazu do grafu	20
4.4 Dijkstrův algoritmus	20
4.5 Algoritmus pro max-arc vzdálenost	21
5 Experimenty	24
5.1 Umělé obrázky	24
5.2 Reálné obrázky	30
6 Závěr	35
Literatura	37

Seznam obrázků

1	Prahování [20]	11
2	Detekce hran [21]	13
3	Minkowského vzdálenost [22]	15
4	Manhattanská vzdálenost [22]	16
5	Eukleidovská vzdálenost [22]	16
6	Čebyševova vzdálenost [22]	17
7	Převedení obrazu do šedého tónu	19
8	Reprezentace obrazu v grafu	20
9	Ukázka průchodu dijkstrovým algoritmem	22
10	Ukázka max-arc vzdálenosti v grafu	23
11	Vliv šumu na obrázek	24
12	Symetrický vertikální řez	25
13	Obdelník	28
14	Reálné obrázky	31

Seznam tabulek

1	Symetrický vertikální řez - Minkowského vzdálenost	25
2	Symetrický vertikální řez - Geodetická vzdálenost	26
3	Symetrický vertikální řez - max-arc vzdálenost	27
4	Obdelník - Minkowského vzdálenost	28
5	Obdelník - Geodetická vzdálenost	29
6	Obdelník - Max-arc vzdálenost	30
7	Reálné obrázky - Minkowského vzdálenost	32
8	Reálné obrázky - Geodetická vzdálenost	33
9	Reálné obrázky - Max-arc vzdálenost	34

Seznam výpisů zdrojového kódu

1	Dijkstrův algoritmus	21
2	Max-arc algoritmus	22

1 Úvod

Segmentace obrazu je jedním z procesů digitálního zpracování obrazu, který rozděluje obraz do více segmentů. Cílem segmentace obrazu je rozdělení obrazu na popředí a na oblasti v obraze, odpovídajícím významným prvkům ve scéně. Princip segmentace obrazu je nejčastěji založen na detekci hran ohraničujících jednotlivé objekty nebo na detekci celých oblastí, kterými jsou jednotlivé objekty v obraze reprezentovány. Segmentace obrazu může být použita například pro rozpoznávání objektů, kompresi obrazu, úpravy obrázků nebo vyhledávání databází obrázků.

Tato práce se zabývá segmentací obrazu s využitím měření vzdálenosti. Jako měřicí metriky jsou použity Minkowského vzdálenost, geodetická vzdálenost a max-arc vzdálenost. V nejjednodušším případě se pro segmentaci obrazu, která je založená na měření vzdálenosti, musí předem určit obrazové body definující pozadí a objekty. Takové pixely se nazývají tzv. „seedy“. Obecně takových seedů může být více, například seedy určující pozadí a seedy určující významné oblasti v obraze. Při segmentaci se prochází jednotlivé pixely a porovnávají se jednotlivé vzdálenosti k seedům. Tímto postupem je nalezen seed s nejkratší vzdáleností k určitému pixelu a následně je zařazen do segmentu, který je reprezentován daným seedem.

Cílem této práce je seznámení se s procesem segmentace obrazu, nejpoužívanějšími technikami a implementace jednotlivých technik založených na měření vzdálenosti. V experimentální části práce se nachází výsledky jednotlivých testů segmentací s využitím měření vzdálenosti, ukázky nejpřesnějších testovaných segmentací a porovnání metrik použitých pro segmentaci.

2 Segmentace obrazu

V této kapitole je vysvětlen pojem segmentace obrazu a jsou zde popsány základní metody pro segmentaci obrazu. Segmentace je proces rozdělení obrazu do segmentů (částí), při kterém jsou objekty separovány od nezajímavého pozadí. Segmentací obrazu se rozumí detekce hran ohraničující jednotlivé objekty nebo detekce celých oblastí, kterými jsou jednotlivé objekty v obraze reprezentovány. Existuje však mnoho různých segmentačních technik [25].

Segmentace obrazu je jedním z nejdůležitějších kroků v analýze obsahu digitálních obrazových dat. Cílem segmentace obrazu je rozdělit obraz do jednotlivých částí, které úzce souvisí s objekty či oblastmi reálného světa zachyceného na obraze. Výsledkem segmentace je v ideálním případě množina vzájemně se nepřekrývajících oblastí. Pokud výsledné oblasti obrazu jednoznačně odpovídají objektům vstupního obrazu, jedná se o kompletní segmentaci. Jestli výsledné oblasti obrazu jednoznačně neodpovídají objektům vstupního obrazu, jedná se pouze o částečnou segmentaci. Často nastává situace, kdy obraz tvoří velmi kontrastní objekty na pozadí se stejným jasnem, například psaný text[1]. V této situaci lze využít jednoduché globální postupy, pomocí kterých lze dosáhnout kompletní segmentaci obrazu na jednotlivé objekty a pozadí. Globální postupy nejsou závislé na kontextu. Globální postupy při řízení procesu segmentace nevyužívají model, ani znalosti o výsledné oblasti.

Segmentační metody se dělí do několika skupin (rozdělení metod inspirováno z [1], [2]). Jedná se o metody založené na detekci hran, oblastně orientované metody, statické metody a znalostní metody. Obecně nelze říci, že některé metody jsou lepší než jiné. Vždy záleží na vlastnostech segmentovaného obrazu a pro různé oblasti se hodí různé metody.

2.1 Statické metody

Statické metody, jsou metody segmentace, které nezohledňují prostorové uspořádání obrázku a více se soustředí na jeho globální vlastnosti. Do této skupiny se řadí např. prahování [16], adaptivní prahování [16], shlukování [17] a amplitudová projekce [1], [2].



Obrázek 1: Prahování [20]

2.1.1 Prahování

Příkladem statistické metody je jedna z nejstarších a nejjednodušších segmentačních technik vůbec, tato technika se nazývá prahování [6] (obrázek 1). Nejjednodušší verze prahování rozděluje pixely segmentovaného obrázku do dvou segmentů (částí) podle toho, zda-li je hodnota jejich jasu (barvy) větší nebo menší než předem určený práh. Přiřazení do segmentů je určeno funkcí:

$$g(i, j) = \begin{cases} 0 & \text{proc} < \text{práh} \\ 1 & \text{proc} \geq \text{práh} \end{cases} \quad (1)$$

Existují i složitější verze prahování, které rozdělují obrazové body do skupin podle více prahů, nebo pomocí analýzy histogramu obrazu určují počet prahů, případně polohu prahu. Práh se nejčastěji umísťuje do nejmenšího minima mezi dvě významná lokální maxima. Co přesně slovo významná označuje, závisí na konkrétním použitém algoritmu. Metoda prahování [6], která vypadá velmi primitivně, je právě díky své jednoduchosti, rychlosti a snadnou implementací velmi důležitá a často používaná metoda pro segmentaci obrazu [1]. Prahování v některých případech dosahuje velmi dobrých výsledků a někdy předčí i složitější a výpočetně náročnější metody.

2.1.2 Adaptivní prahování


Adaptivní neboli proměnné prahování [8] se liší od základního prahování tím, že v různých částech má jinou hodnotu prahu. Obraz je nejdříve rozdělen do několika částí, pro každou část je nalezen práh (prahy jednotlivých oblastí mohou být interpolovány) a nakonec se provede prahování pro každou část s jejím konkrétním prahem.

2.2 Metody založené na detekci hran

Detekce hran [6] se řadí jako jedna z nejvýznamnějších oblastí v nižší úrovni zpracování obrazu. Jednotlivé hrany jsou definovány body obrazu, kde se hodnota jasu prudce mění. Každá hrana je reprezentována velikostí a směrem. Jednotlivé změny a přerušení v jasu (barvě) obrazu, které značí fyzickou polohu objektů, jsou jedny z nejzákladnějších charakteristik obrazu. Jasové hrany jsou definovány jako lokální změny jasu obrazu a hraniční segmenty jsou definovány jako globální změny jasu obrazu. Skoková funkce je ideální model hrany. V reálných obrazech jsou změny v jasech postupné, nikoli skokové, proto je výhodnější použít šikmou funkci. V případech kdy se obě definované funkce objeví v obrazu vedle sebe, vznikají další dva typy hran, tyto hrany se nazývají čára a střecha.

Proces detekce se rozděluje na tři části: filtrování, diferenciaci a detekci. V části filtrování se potlačuje šum, který vznikl při nevhodném nastavení snímacího zařízení, vzorkování obrazu nebo rozmazání. Diferenciaci pak zvýrazní oblasti v obraze, kde je změna velikosti jasu obrazu významná. Nakonec se detekují a lokalizují body, kde je změna velikosti jasu nejvýznamnější,

viz [1], [15]. Metody založené na detekci hran jsou například Hranové detektory [7], Houghovy transformace [10], Aktivní kontury [11], Level-sets [12] a Isosurfaces [13]. Na obrázku 2 je ukázka detekce hran.



Obrázek 2: Detekce hran [21]

2.2.1 Hranové detektory

Pro metody založené na detekci hran [7] existují dvě hlavní skupiny. Metody, které využívají první derivaci a metody, které využívají druhou derivaci. Při použití první derivace je výsledný hranový gradient porovnán s prahem, který určuje, jestli se jedná o hrany. U metod druhé derivace je výskyt hrany detekován, pokud je prostorová změna v polaritě druhé derivace dostatečně významná [1].

2.3 Oblastně orientované metody

Oblastně orientované metody [23] hledají propojené regiony na základě nějaké podobnosti obrazových bodů v daných regionech. Cílem je vyprodukovat propojené regiony, které jsou co největší (tzn., vyprodukovat co nejméně možných regionů), což umožňuje určitou flexibilitu v každém regionu. Nicméně pokud je povoleno příliš mnoho flexibility, je možné sloučit některé objekty s pozadím. Na druhou stranu, pokud je požadováno, aby barvy jednotlivých obrazových bodů v oblasti byly velmi podobné, lze segmentovat i oblasti, které nemají být odděleny. Cílem je najít oblasti, které odpovídají objektům, jak je vidí člověk, což vůbec není snadný cíl.

Narůstání oblastí (Region growing) [23] je postup zdola nahoru. Region začíná vybranými obrazovými body (tzv. "seedy") a pak roste přidáním sousedních pixelů, které mají podobné vlastnosti (například jas, barva, struktura, gradient, geometrické vlastnosti). Je možné určit odchylku, při které se narůstání oblasti zastaví. Narůstání oblasti se zastaví, pokud se narazí na obrazový bod, který se v dané odchylce nenachází. Seedy mohou být zvoleny ručně nebo automaticky.

Tento přístup má několik nežádoucích účinků. Současný region dominuje růstu oblasti a jednotlivé nejednoznačnosti kolem přilehlých oblastí nemusí být vyřešeny správně. Různé umístění seedů může dát různé výsledky segmentace a problémy mohou nastat, pokud seed leží na hraně. Jedna z možností, jak se tomuto problému vyhnout, je vytvořit více seedů a provést segmentaci z několika seedů současně, viz.[2].

Příkladem oblastně orientovaných segmentačních metod jsou techniky Split and merge a Watershed Transform [9]. Do této kategorie spadá i segmentace založená na měření vzdálenosti.

2.4 Segmentace založená na měření vzdálenosti

Segmentace založená na měření vzdálenosti se může zařadit do oblastně orientovaných metod, díky tomu, že tyto metody používají předem vybrané sady obrazových bodů (tzv. "seedy"). K segmentaci se používají převážně dva různé přístupy, první je na základě Eukleidovského prostoru (zde se řadí Minkowského vzdálenost) a druhý na základě grafových algoritmů (zde se řadí geodetická[19] a max-arc vzdálenost). Pro segmentaci, která je založena na měření vzdálenosti se musí nejprve určit jednotlivé seedy. Určení seedů je možné provádět ručně nebo automaticky (v této práci jsou seedy určeny ručně). Minimální počet určených seedů je 2. Jeden seed reprezentuje objekt a jeden seed reprezentuje pozadí. Výsledná segmentace s využitím měření vzdálenosti je závislá na poloze jednotlivých seedů, proto se v praxi používá více seedů najednou. Použití více seedů zvětšuje pravděpodobnost přesnější segmentace. Obecně platí, že čím více seedů je použito, tím bude přesnější výsledná segmentace.

Jestliže máme definované seedy $O = \{o_1, \dots, o_{n-1}, o_n\}$, které reprezentují objekty a seedy $B = \{b_1, \dots, b_{m-1}, b_m\}$, které reprezentují pozadí, je možné začít proces segmentace s využitím měření vzdálenosti. Při segmentaci se prochází všechny pixely p a následně se porovnává jejich vzdálenost ke všem seedům O a B , pokud nejbližší seed $s \in O$ je pixel označen za objekt, v opačném případě je pixel označen za pozadí. Vzdálenost mezi pixely a jednotlivými seedy může být definována různě. V této práci je pro výpočet jednotlivých vzdáleností použita Minkowského vzdálenost, geodetická vzdálenost a max-arc vzdálenost. Jednotlivé vzdálenostní metriky jsou popsány v kapitole 3.

2.5 Znalostní metody

Znalostní metody [24] vychází z předchozí znalosti o segmentovaném obraze. Ve většině případů se vytváří vzor nebo model a poté se v obraze hledá shoda s tímto modelem. Pomocí znalostních metod je možné získat velice dobré výsledky pro obrazy s jednoduchými objekty, ale obecně platí, že čím složitější objekty se na obraze nacházejí, tím je kvalita (přesnost) segmentace těmito metodami nižší [1]. Do znalostních segmentačních technik patří například technika Appearance Models (AAM) [14]


3 Metriky pro segmentaci využívající měření vzdálenosti

Princip segmentace založené na měření vzdálenosti je popsán v kapitole 2.4. V této kapitole se nachází příklady některých metrik, podle kterých lze při segmentaci obrazu určit, do kterého segmentu daný obrazový bod patří.

3.1 Minkowského vzdálenost

Minkowského vzdálenost[18] vychází z geometrického prostoru. Minkowského vzdálenost bývá nazývána také jako L_p vzdálenost, kde p představuje parametr funkce. Tuto vzdálenost lze definovat jako parametrizovanou vzdálenostní funkci nad n -rozměrným prostorem. Minkowského vzdálenost lze tedy použít ve vektorovém prostoru, respektive v prostoru se souřadným systémem. Obecná definice Minkowského vzdálenosti mezi dvěma body $X = (x_1, x_2, \dots, x_n)$ a $Y = (y_1, y_2, \dots, y_n) \in R_n$ s parametrem p je následující:

$$d(X, Y) = \sum_{i=1}^n (|x_i - y_i|^p)^{1/p} \quad (2)$$



Obrázek 3: Minkowského vzdálenost [22]


3.1.1 Manhattanská vzdálenost

Manhattanská vzdálenost[18] je speciálním případem Minkowského vzdálenosti, pro $p = 1$. Obecný termín pro Manhattanskou normu je norma L^1 nebo vzdálenost L^1 .

$$l(X, Y) = \left(\sum_{i=1}^n |x_i - y_i| \right) \quad (3)$$

Při segmentaci podle Manhattanské vzdálenosti, se v této práci vychází z následující definice, kde x_i a y_i jsou souřadnice i -tého bodu a z_i je jas bodu i -tého bodu.

$$d(X, Y) = (|x_1 - x_2| + |y_1 - y_2| + |z_1 - z_2|) \quad (4)$$



$$\begin{aligned} p &= 2^0 \\ &= 1 \end{aligned}$$

Obrázek 4: Manhattanská vzdálenost [22]


3.1.2 Eukleidovská vzdálenost

Eukleidovská vzdálenost[18] je speciálním případem Minkowského vzdálenosti, pro $p = 2$. Obecný termín pro Eukleidovskou normu je norma L^2 nebo vzdálenost L^2 *i-tého* bodu. L^1 nebo vzdálenost L^1 .

$$d(X, Y) = \left(\sum_{i=1}^n |x_i - y_i|^2 \right)^{1/2} \quad (5)$$

Při segmentaci podle Eukleidovské vzdálenosti se v této práci vychází z následující definice, kde x_i a y_i jsou souřadnice *i-tého* bodu a z_i je jas *i-tého* bodu.

$$d(X, Y) = \left(|x_1 - x_2|^2 + |y_1 - y_2|^2 + |z_1 - z_2|^2 \right)^{1/2} \quad (6)$$



$$\begin{aligned} p &= 2^1 \\ &= 2 \end{aligned}$$


Obrázek 5: Eukleidovská vzdálenost [22]

3.2 Čebyševova vzdálenost

Jedná se o speciální případ Minkowského vzdálenosti, kde $p = \infty$. Čebyševova vzdálenost[18] je také známa jako vzdálenost L^∞ . Tato vzdálenost je výhodná pro objekty, u kterých se upřed-

nostňuje odlišnost individuálních parametrů před celkem. Vzorec pro Čebyševovu vzdálenost

$$\lim_{k \rightarrow \infty} = \left(\sum_{i=1}^n |p_i - q_i| \right)^{1/k} \quad (7)$$



$$p = 2^\infty$$

$$= \infty$$

Obrázek 6: Čebyševova vzdálenost [22]

3.3 Geodetická vzdálenost

Pro segmentaci s využitím geodetické vzdálenosti [19] je potřeba převést vstupní obraz na graf G s nezáporně ohodnocenými hranami E . Vytvořením grafu G je věnována kapitola 4.2.

Předpokládejme, že $P = \{p_1, p_2, \dots, p_n\}$ je cesta mezi p_1 až p_n , kde p_i a p_{i+1} jsou sousední propojené vrcholy. Délka cesty je definována předpisem

$$l(P) = \sum_{i=1}^{n-1} w(p_i, p_{i+1}) \quad (8)$$

To jest jako součet sousedních vzdáleností w mezi sousedními body v cestě. Váha w mezi dvěma sousedními body A a B je dána pomocí $w = \|z_A - z_B\|$, kde z_A je jas bodu A a z_B je jas bodu B . Existuje mnoho způsobů jak počítat váhu hrany w . V této práci se bude váha hrany w počítat pomocí vzorce v kapitole 4.3.

Dejme tomu, že P_{AB} je množina všech cest mezi vrcholy A a B . Geodetická vzdálenost je poté definována jako

$$d_g(A, B) = \min_{P \in P_{AB}} l(P) \quad (9)$$

Při segmentaci založené na geodetické vzdálenosti se nejprve zjistí nejkratší cesta ze všech seedů do obrazového bodu X (v této práci se používá Dijkstrův algoritmus, viz. kapitola 4.4). Poté se označí obrazový bod X jako objekt nebo pozadí, na základě nejbližšího seedu.

3.4 Max-arc vzdálenost

Pro segmentaci s využitím max-arc vzdálenosti je potřeba vytvořit stejný graf jako v případě segmentace s využitím geodetické vzdálenosti. Max-arc vzdálenost lze popsat jako Čebyševovu vzdálenost na grafu. Cesta P je definována v předchozí vzdálenosti. Délka cesty z bodu A do bodu B je v případě max-arc vzdálenosti definována jako

$$l(P) = \max\{w_{p_1,p_2}, \dots, w_{p_{n-1},p_n}\} \quad (10)$$

Vzdálenost w mezi dvěma body A a B je váha hrany v grafu mezi body A a B . Dejme tomu, že P_{AB} je množina všech cest mezi vrcholy A a B . max-arc vzdálenost je poté definována jako:

$$d_m = \min_{P \in P_{AB}} l(P) \quad (11)$$

Vzdálenost d_m je výsledná max-arc vzdálenost z bodu A do bodu B , která odpovídá nejnižší hodnotě z maximální hrany v cestě.

4 Implementace

4.1 Načtení obrazu

Pro načítání obrazů je v této práci použita knihovna OpenCV. OpenCV (Open Computer Vision) je open source sada knihoven, která slouží pro práci s digitálními obrazy a počítačovým viděním v reálném čase. S knihovnou lze vyvíjet aplikace pro rozpoznávání gest, tváří, objektů atp. Je tedy využívána zejména v oblasti robotiky a pro implementaci aplikací z oblasti experimentálních rozhraní pro styk člověka s počítačem [4].

4.2 Předzpracování obrazu

Po úspěšném získání obrazu je k dispozici digitální obraz pozorované scény. Je možné, že obraz bude zkreslen díky způsobu snímání nebo z důvodu nevhodných podmínek při jeho průběhu. Pokud je znám charakter zkreslení, je možné takovou chybu opravit pomocí korekcí, které jsou jednou z metod předpracování obrazu. Pro usnadnění analýzy obrazu, identifikaci objektů nebo pouze pro zvýraznění důležitých rysů obrazu pro jednodušší pozorování člověkem existuje velké množství metod[5]. Základními metodami pro předzpracování obrazu jsou filtrace a ostření, jasová transformace a geometrické transformace.

V této práci se před převedením obrazu do grafu nejprve provede převod obrazu do šedotónu (hodnota jednotlivých obrazových bodů 0-255). V experimentální části je dále testován vliv Gaussova rozostření na segmentaci obrazu. Použitím Gaussova rozostření je na mysli aplikace filtru, který odpovídá dvoudimenzionální Gaussově funkci

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (12)$$

kde σ je rozptylem hodnot.

Jelikož Gaussovo rozostření nerozlišuje mezi šumem a signálem v obraze, jeho aplikací lze ztratit i část relevantních výsledků. Gaussovo rozostření se aplikuje hlavně z důvodu potlačení šumu a omezení počtu málo významných hran v obraze. Na obrázku 7 je příklad převedení obrazu do šedotónu.




Obrázek 7: Převedení obrazu do šedého tónu

4.3 Převedení obrazu do grafu

Pro segmentaci s využitím geodetické vzdálenosti a max-arc vzdálenosti je nutné převést obraz do grafu G . Jednotlivé obrazové body lze brát jako vrcholy V grafu G . Jednotlivé hodnoty hran v grafu G se určí podle následující rovnice

$$w_{i,j} = 1.0 - e^{-\frac{(z_i - z_j)^2}{2\sigma^2}} + \beta \quad (13)$$

kde z_i, z_j jsou hodnoty jasu ve vrcholech v_i, v_j . Hodnota β určuje cenu pro používání hrany, bez ohledu na rozdíl v jasech. Pokud je hodnota $\beta = 0$, tak jsou obrazové body se stejným jasnem velmi blízké. Body mohou být geometricky vzdálené v rovině xy , ale měly by vytvořit jeden segment. Přestože toto nastavení nesplňuje metrické podmínky, může být užitečné při udržení malých nebo dokonce nulových vzdáleností v oblastech s konstantním jasnem. V experimentální části se pracuje s hodnotou $\beta = 0$. Pro určení sousedních hran je použit 4-sousední.



(a) 4-sousední graf

Obrázek 8: Reprezentace obrazu v grafu

4.4 Dijkstrův algoritmus

Dijkstrův algoritmus [3] lze také chápat jako určité zobecnění postupu prohledávání grafu do šířky. Také při něm se počíná výchozím uzlem s systematicky šíří vlna ve směru k dosud neobjeveným částem grafu. Tato vlna pohlcuje jen takové uzly, k nimž byla již nalezena nejkratší cesta. Důležitým předpokladem použitelnosti Dijkstrova algoritmu je, aby ohodnocení hran w mělo pouze nezáporné hodnoty. Tento celý odstavec se tedy zabývá řešením základní úlohy o vzdálenostech z jednoho uzlu do všech ostatních na orientovaném grafu G s nezáporným ohodnocením hran $w : H \rightarrow R^+$, kde H je množina vrcholů grafu G a U je množina hran grafu G .

Specifičnost Dijkstrova algoritmu spočívá pouze ve způsobu výběru hran pro zařazení do prioritní fronty. Algoritmus postupně rozšiřuje množinu uzlů S , jejichž aproximovaná vzdálenost $d[u]$ se již shoduje se skutečnou w -vzdáleností $d_w(s, u)$. Stejně jako v algoritmu prohledávání do šířky se tyto uzly mohou označit jako uzavřené. Zbývající uzly grafu G , tedy $U - S$, jsou umístěny v prioritní frontě Q seřazené vzestupně podle hodnot $d[u]$. Na začátku této fronty jsou vždy uzly

otevřené, neboť jen ony mají přiřazenu konečnou hodnotu $d[u]$. Následující vyjádření Dijkstrova algoritmu předpokládá reprezentaci grafu pomocí seznamu následníků.

```

1  DIJKSTRA (G,s,w)
2
3      for u~in U~do
4          d[u] := nekonečno      {nastavení všech velikostí na nekonečno}
5
6          d[s] := 0              {nastavení počáteční velikosti na 0}
7          prioritní fronta Q
8          Q.push(0, s)
9
10         while fronta Q~neprázdná do
11             u~:= Q.pop().second      {vyber netrvalý vrchol s nejmenší d[s]}
12
13             for v~in Adj[u] do
14                 if d[v] > d[u] + w(u, v) then
15                     d[v] := d[u] + w(u, v)
16                     Q.push(d[v], v)

```


Výpis 1: Dijkstrův algoritmus

Nejkratší dosud objevená cesta k uzlu u je uložena v $d[u]$, pokud $d[u] = \text{nekonečno}$, tzn. že uzel u ještě nebyl nalezen. Je vidět, že při prvním průchodu cyklem *while* se jako nejbližší vybere právě uzel s , který má jako jediný přiřazenu konečnou (nulovou) hodnotu $d[u]$. Při rozhodování o vložení vrcholu v do prioritní fronty Q porovnáváme, jestli není součet $w(u, v) + d[u]$ menší než hodnota cesty do vrcholu v . Pokud platí, že $w(u, v) + d[u] < d[v]$, tak vložíme do $d[v]$ hodnotu $d[u] + w(u, v)$ a do prioritní fronty Q vložíme $(d[v], v)$. Do této fronty se však žádný uzel neukládá opakovaně, takže z ní bude vybrán právě jednou a hlavní cyklus na řádcích se bude opakovat $|U|$ -krát, viz.[3].

Dijkstrův algoritmus je v této práci modifikován tak, aby bylo možné hledat cestu z více zdrojových vrcholů najednou. Této funkčnosti bylo dosaženo tak, že pro každý zdrojový vrchol s_i je nastavena vzdálenost $d[i] = 0$ a následně je vrchol vložen do prioritní fronty. Na obrázku 9 lze vidět průchod Dijkstrovým algoritmem a vyhledání nejkratší cesty v nezáporně ohodnoceném grafu.

4.5 Algoritmus pro max-arc vzdálenost

Algoritmus pro nalezení max-arc vzdálenosti je modifikace Dijkstrova algoritmu, kde se nerozhoduje na základě součtu hran v cestě, ale na základě největší nalezené hrany v cestě. Stejně jako u Dijkstrova algoritmu, ohodnocení stran musí být nezáporné.



Obrázek 9: Ukázka průchodu dijkstrovým algoritmem

Pro porovnání velikosti hran se vytvoří další proměnná *weight*, která slouží pro uschování max-arc hodnoty do v . Do proměnné *weight* se vloží váha hrany z u do v ($weight = w(u, v)$). Při rozhodování o vložení vrcholu v do prioritní fronty Q se porovnává, jestli není váha hrany $w(u, v)$ menší než hodnota cesty ze zdroje $d[u]$. Pokud platí, že $w(u, v) < d[u]$, tak se vloží do *weight* hodnota $d[u]$. Následuje porovnání dosažené vzdálenosti do v s hodnotou *weight*. Pokud $d[v] > weight$, tak se nastaví hodnota $d[v] = weight$.


```

1  MAXARC (G,s,w)
2
3  for u~in U~do
4      d[u] := nekonecno {nastaveni vseh velikosti na nekonecno}
5      p[u] := NULL      {nastaveni vseh predchozich uzlu na NULL}
6
7      prioritni fronta Q~z vrcholu V~s prioritami d[u]
8
9  while fronta Q~neprazdna do
10     u~:= Q.pop()      {vyber netrvaly vrchol s-nejmensim d[s]}
11
12     for v~in Adj[u] do
13         weight := w(u, v)
14         if (d[u] > weight) then
15             weight := d[u]
16
17         if (d[v] > weight) then
18             d[v] = weight
19             p[v] :=u
20             Q.push(v, d[v])

```

Výpis 2: Max-arc algoritmus

Nejkratší cestu k dosud objeveným uzlům tvoří stejně jako u Dijkstrova algoritmu silně vytažené hrany, hodnoty $d[u]$ jsou uvedeny uvnitř uzlů. Lze vidět, že při prvním průchodu cyklem *while* se jako nejbližší vybere právě uzel s , který má jako jediný přiřazenu konečnou (nulovou) hodnotu $d[u]$. Při porovnání velikosti hran v nalezené cestě do u s velikostí hrany do v se v případě úpravy hodnoty $d[v]$ předpokládá zařazení uzlu v na odpovídající místo ve frontě Q . Do této fronty se však žádný uzel neukládá opakovaně.



Obrázek 10: Ukázka max-arc vzdálenosti v grafu


5 Experimenty

V této kapitole se nachází testování segmentačních technik s využitím měření vzdáleností a porovnání výsledků jednotlivých technik. Experimentální část je rozdělena na dvě podčásti. V první části se nachází testování segmentačních metod s využitím vzdálenosti nad umělými obrázky (přesné obrázky, které byly vytvořeny pomocí grafického editoru) a ve druhé části se nachází testování segmenčních metod s využitím vzdálenosti nad reálnými obrázky. Na obrázcích vytvořených z grafického editoru lze snadněji rozpoznat chování jednotlivých segmentačních metod v určitých situacích, které lze jednodušeji vytvořit. V této části se testuje segmentace s využitím Minkowského vzdálenosti, geodetické a max-arc vzdálenosti. U Minkowského vzdálenosti jsou testovány hodnoty $p = \{0.5, 1, 2, 4\}$. U geodetické a max-arc vzdálenosti je testován vliv hodnoty σ , pomocí které se mění váhy hran v grafu s použitím vzorce uvedeného v kapitole 4.2.

Z důvodu většího množství testů je pro každý test ukázán pouze zdrojový obrázek se seedy a výslednou segmentací, u které bylo dosaženo nejlepších výsledků. Každý test dále obsahuje tabulku výsledků pro segmentaci s využitím Minkowského vzdálenosti, tabulku výsledků pro segmentaci s využitím geodetické vzdálenosti a tabulku výsledků segmentace s využitím max-arc vzdálenosti. Výsledky zapsané v jednotlivých tabulkách udávají procentuální odchylku (chybovost) od předpokládaného ideálního výsledku. V ideálním případě je chybovost nulová.

5.1 Umělé obrázky

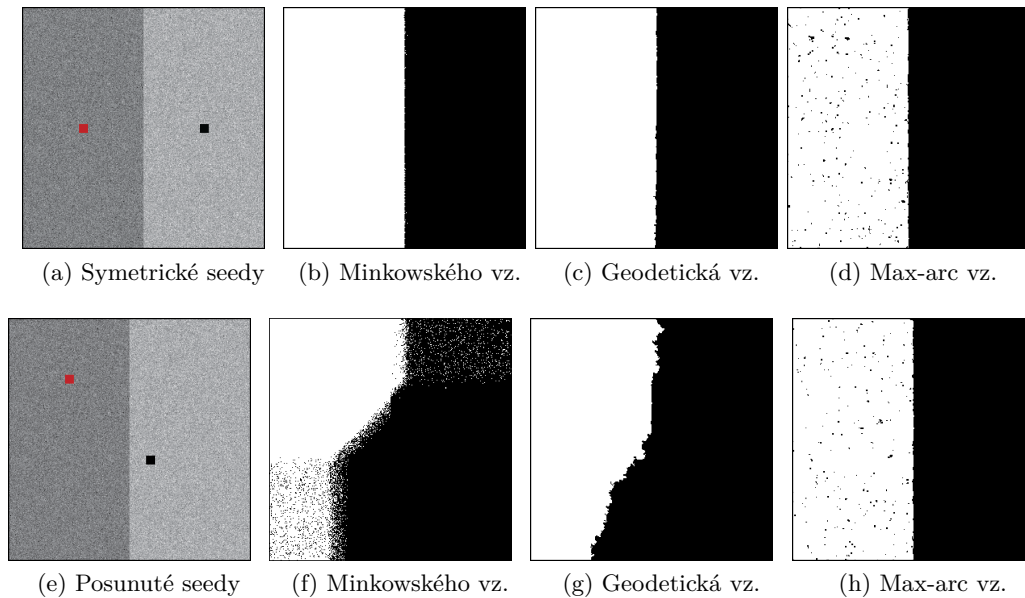
Vytvoření umělých obrázků s pomocí grafického editoru bylo zvoleno z důvodu přesnosti a jednoduchosti vytvoření obrazu s velkým přechodem mezi hranami a snadnému nasimulování různých situací pro testování segmentace obrazu s využitím měření vzdálenosti. V této sekci je testován i vliv uměle vytvořeného šumu na výsledky segmentace. Velikost šumu ω se testuje pro hodnoty $\omega \in \{0.1, 0.2, 0.3, 0.4, 0.5\}$. Následující obrázek 11 slouží pro představu o vlivu šumu ω na obraz. Pro ujasnění významu ω , hodnota ω značí velikost odchylky v gaussovském šumu. Odchylka $\omega > 0.5$ nebyla testována, protože velikost šumu je příliš vysoká a výsledná segmentace s využitím měření vzdálenosti je již velmi nepřesná.



Hodnota ω určuje velikost odchylky gaussovského šumu.

Obrázek 11: Vliv šumu na obrázek

Generování šumu je před každým testem náhodné, z toho důvodu jsou všechny testy nad umělými obrázky provedeny 1000-krát. Velikost všech umělých testovacích obrázků bude 300x300 pixelů. Pro první test byla snaha vytvořit co nejjednodušší testovací obrázek pro segmentaci. Tento obrázek jsem rozdělil vertikálně na dvě stejné poloviny. Velikost šumu pro obrázek 12 je $\omega = 0.4$, tuto velikost jsem vybral z důvodu podobnosti všech výsledků, kde $\omega < 0.4$. Na obrázku 12a můžeme vidět symetricky určené seedy, pro co nejpřesnější výsledky segmentace. Na obrázku 12e byly seedy posunuty do jednotlivých rohů, aby bylo možné porovnat a ukázat vliv umístění jednotlivých seedů na výsledky segmentace. Seed s černou barvou reprezentuje pozadí a seed s červenou barvou reprezentuje objekt.



Obrázek 12: Symetrický vertikální řez

Tabulka 1: V tabulce 1a se nachází výsledky segmentace s využitím Minkowského vzdálenosti pro obraz 12a a v tabulce 1b se nachází výsledky segmentace s využitím Minkowského vzdálenosti nad obrazem 12e. Parametr p udává hodnotu v Minkowského vzdálenosti a parametr ω udává odchylku gaussovského šumu. Jednotlivé hodnoty v tabulce udávají výslednou chybovost segmentace s využitím Minkowského vzdálenosti.

(a)					(b)				
	$p = 0.5$	$p = 1$	$p = 2$	$p = 4$		$p = 0.5$	$p = 1$	$p = 2$	$p = 4$
$\omega = 0.1$	0.000	0.000	0.000	0.000	$\omega = 0.1$	0.465	2.874	11.811	18.591
$\omega = 0.2$	0.085	0.024	0.014	0.006	$\omega = 0.2$	3.414	8.476	21.51	25.298
$\omega = 0.3$	0.352	0.084	0.048	0.044	$\omega = 0.3$	10.139	12.692	24.948	25.861
$\omega = 0.4$	0.745	0.216	0.109	0.092	$\omega = 0.4$	15.561	15.544	25.189	26.082
$\omega = 0.5$	0.917	0.227	0.103	0.083	$\omega = 0.5$	18.448	16.818	25.633	26.681
čas(s)	1.284	1.291	1.285	1.276	čas(s)	0.134	0.115	1.264	1.276

Jelikož se v Minkowského vzdálenosti bere v potaz fyzické umístění a jas obrazových bodů současně, z tohoto důvodu je výsledná chybovost segmentace nad obrazem 12a velmi nízká. V nejhorším případě je chybovost výsledné segmentace s využitím měření vzdálenosti 0.91%, při hodnotě $p = 0.5$. Nejlepší výsledky pro všechny hodnoty σ měla právě Minkowského vzdálenost $p = 4$, která těží ze symetrického umístění seedů a symetrického rozdělení testovacího obrázku.

Výsledky segmentace při použití Minkowského vzdálenosti pro obraz 12e se nachází v tabulce 1b. Při šumu $\sigma = 0.1, 0.2, 0.3$ kdy hraje dominantní roli jas pixelu, byla segmentace nejúspěšnější pro vzdálenost s parametrem $p = 0.5$, ale pokud je σ příliš vysoká ($\sigma = 0.4, 0.5$), tak získává na prioritě fyzické umístění seedu. Důležitost umístění seedu lze pozorovat, při porovnání výsledků pro obrázek 12a a 12e. Kdy v prvním případě byla nejúspěšnější segmentace s využitím Minkowského vzdálenosti $p = 4$, zatímco v druhém případě (po posunu seedů) byla tato metrika nejméně úspěšná.

Tabulka 2: V tabulce 2a se nachází výsledky segmentace s využitím geodetické vzdálenosti pro obraz 12a a v tabulce 5a se nachází výsledky segmentace s využitím Minkowského vzdálenosti nad obrazem 12e. Parametr ω značí odchylku gaussovského šumu a parametr σ mění hodnotu hrany v grafu podle vzorce uvedeném v kapitole 4.3. Jednotlivé hodnoty v tabulce udávají průměrnou procentuální chybovost výsledků segmentace s využitím geodetické vzdálenosti.

(a)										
ω	$\sigma = 0.1$	$\sigma = 0.2$	$\sigma = 0.3$	$\sigma = 0.4$	$\sigma = 0.5$	$\sigma = 0.6$	$\sigma = 0.7$	$\sigma = 0.8$	$\sigma = 0.9$	čas (s)
0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.142
0.2	0.521	0.086	0.061	0.059	0.059	0.062	0.057	0.052	0.053	0.139
0.3	0.928	0.706	0.678	0.673	0.680	0.681	0.681	0.663	0.649	0.135
0.4	1.256	1.239	1.268	1.235	1.272	1.294	1.236	1.252	1.232	0.138
0.5	1.593	1.586	1.616	1.599	1.599	1.589	1.572	1.627	1.588	0.142

(b)										
ω	$\sigma = 0.1$	$\sigma = 0.2$	$\sigma = 0.3$	$\sigma = 0.4$	$\sigma = 0.5$	$\sigma = 0.6$	$\sigma = 0.7$	$\sigma = 0.8$	$\sigma = 0.9$	čas (s)
0.1	19.429	5.002	0.499	0.134	0.089	0.061	0.041	0.037	0.037	0.141
0.2	22.432	18.766	18.056	17.618	17.603	17.549	17.596	17.449	17.659	0.135
0.3	24.215	23.174	23.122	22.988	22.988	22.988	23.089	23.046	22.984	0.128
0.4	25.109	24.601	24.566	24.693	24.659	24.659	24.447	24.559	24.560	0.139
0.5	25.398	25.393	25.288	25.357	25.198	25.239	25.356	25.186	25.356	0.135

Při testování geodetické vzdálenosti se upravuje hodnota σ , popsaná v kapitole 4.3, a zjišťuje se její vliv na výsledek segmentace. Hodnotou σ se mění váhy hran v grafu. Podle tabulky 2a je ve všech testech nejméně vhodná hodnota $\sigma = 0.1$. Naopak jako nejvhodnější hodnota vychází $\sigma = 0.9$. Nejlepší výsledky pro $\sigma = 0.7$ a $\sigma = 0.8$ byly ve čtyřech případech. Podle tabulky, se jeví jako nejoptimálnější hodnota pro segmentaci s využitím geodetické vzdálenosti $\sigma \in \{0.7, 0.8, 0.9\}$. V tabulce 5a lze pozorovat vliv Gaussova filtru pro obrázky poničené šumem. V krajním případě, například při segmentaci obrazu 12e s parametrem $\sigma = 0.1$ a šumem $\omega = 0.1$ lze Gaussovým filtrem snížit chybovost segmentace o 19,429%.

Tabulka 3: V tabulce 3a se nachází výsledky segmentace s využitím max-arc vzdálenosti pro obraz 12a a v tabulce 3b se nachází výsledky segmentace s využitím max-arc vzdálenosti nad obrazem 12e. Parametr ω značí odchylku gaussovského šumu a parametr σ mění hodnotu hrany v grafu podle vzorce uvedeném v kapitole 4.3. Jednotlivé hodnoty zapsané v tabulce udávají výslednou průměrnou chybovost segmentace s využitím max-arc vzdálenosti.

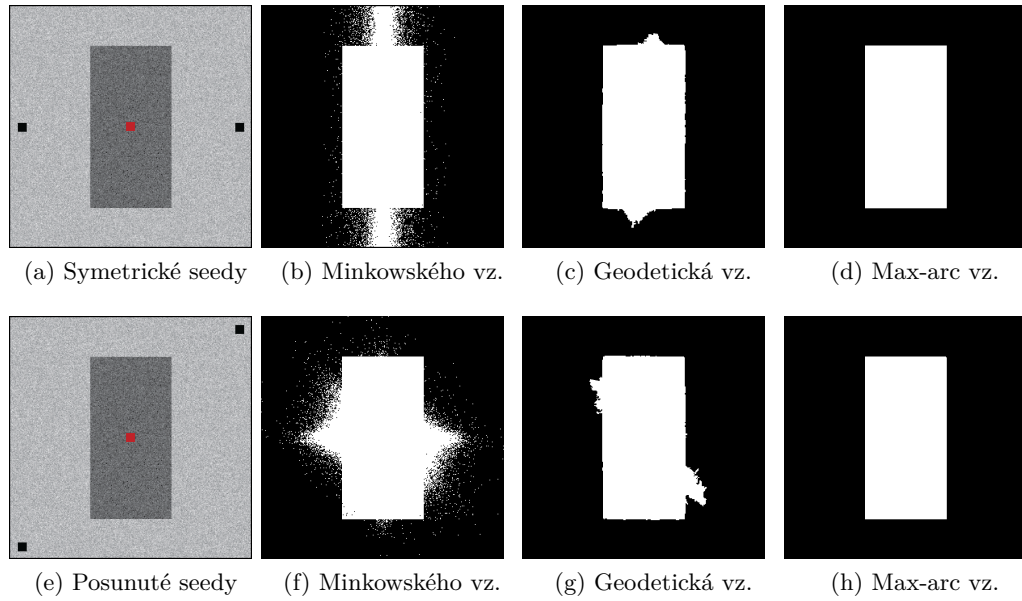
(a)

ω	$\sigma = 0.1$	$\sigma = 0.2$	$\sigma = 0.3$	$\sigma = 0.4$	$\sigma = 0.5$	$\sigma = 0.6$	$\sigma = 0.7$	$\sigma = 0.8$	$\sigma = 0.9$	čas (s)
0.1	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
0.2	2.525	2.575	2.569	2.571	2.561	2.568	2.576	2.571	2.559	0.000
0.3	23.261	23.152	22.747	23.120	22.580	22.874	22.050	22.261	22.487	0.000
0.4	36.813	36.547	36.157	36.547	36.874	36.824	36.217	35.548	36.376	0.000
0.5	40.076	40.942	41.942	41.076	40.125	41.078	40.512	41.412	42.027	0.000

(b)

ω	$\sigma = 0.1$	$\sigma = 0.2$	$\sigma = 0.3$	$\sigma = 0.4$	$\sigma = 0.5$	$\sigma = 0.6$	$\sigma = 0.7$	$\sigma = 0.8$	$\sigma = 0.9$	čas (s)
0.1	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
0.2	2.525	2.575	2.569	2.571	2.561	2.568	2.576	2.571	2.559	0.000
0.3	22.428	23.491	22.842	22.988	23.089	22.985	23.122	22.842	22.487	0.000
0.4	39.408	38.808	39.134	38.544	38.428	36.824	38.947	38.192	38.351	0.000
0.5	40.076	41.076	41.942	38.322	40.125	41.076	39.332	42.027	40.125	0.000

Z výsledků segmentace s využitím max-arc vzdálenosti, které jsou zapsány v tabulce 3a. vyplývá, že změna hodnoty σ nemá žádný vliv na výsledek segmentace. Podle výsledků se zdá, že vzdálenost je nezávislá na změnu hodnoty jednotlivých hran pomocí vzorečku popsáném v kapitole 4.3, protože se hledá pouze největší váha v cestě od bodu A do bodu B , tzn. že jestli hrana mezi bodem A a bodem B má hodnotu 1 nebo 0.1 nemá vliv na výsledek. Podle tabulky 3b se max-arc vzdálenost jeví jako robustní v umístění seedů na stejném typu pozadí. Tato robustnost je dána tím, že se v případě max-arc vzdálenosti nebere v úvahu celá cesta mezi dvěma body, ale pouze největší hrana, tudíž se nebere v úvahu ani vzdálenost mezi dvěma body. Výsledná segmentace pro obraz 12a a 12e je velmi podobná.



Obrázek 13: Obdelník

Pro následující test jsem vytvořil obrázek, který obsahuje ve svém středu obdelník. Seedy na obrázku 13a jsem určil symetrické. Pro obrázek 13e jsem umístil seedy do dvou protilehlých rohů, aby vzdálenost do zbylých dvou rohů byla jiná. Seedy s červenou barvou určují objekt a seedy s černou barvou určují pozadí. Pro ukázkou výsledků jednotlivých segmentačních technik byla zvolena velikost šumu $\omega = 0.2$, protože pro $\omega < 0.2$ byly výsledky příliš podobné a pro $\omega > 0.2$ příliš nepřesné. Velikost jednotlivých testovacích obrázků je 300x300 pixelů.

Tabulka 4: V tabulce 4a se nachází výsledky segmentace s využitím Minkowského vzdálenosti pro obraz 13a a v tabulce 4b se nachází výsledky segmentace s využitím Minkowského vzdálenosti nad obrazem 13e. Parametr p udává hodnotu v Minkowské vzdálenosti a parametr ω udává odchylku gaussianského šumu. Jednotlivé hodnoty v tabulce udávají výslednou průměrnou chybovost segmentace s využitím Minkowského vzdálenosti.

(a)					(b)				
	$p = 0.5$	$p = 1$	$p = 2$	$p = 4$		$p = 0.5$	$p = 1$	$p = 2$	$p = 4$
$\omega = 0.1$	1.866	2.932	4.313	4.851	$\omega = 0.1$	1.194	6.615	32.381	39.627
$\omega = 0.2$	4.912	10.097	13.676	16.747	$\omega = 0.2$	4.582	19.814	43.206	46.161
$\omega = 0.3$	10.518	15.631	18.891	20.438	$\omega = 0.3$	14.191	34.771	45.667	47.207
$\omega = 0.4$	18.378	18.778	20.541	21.404	$\omega = 0.4$	20.443	34.807	46.878	47.472
$\omega = 0.5$	19.704	19.904	21.351	21.824	$\omega = 0.5$	23.412	37.407	47.168	47.719
čas(s)	2.104	2.0151	2.101	2.218	čas(s)	1.921	1.942	1.928	1.928

Jako první test byla provedena segmentace obrazu s využitím Minkowského vzdálenosti nad testovacím obrázkem 13a, výsledná chybovost segmentace pro jednotlivé hodnoty parametru p je zapsaná v tabulce 4a. Výsledná přesnost segmentace je velmi nízká, nejlépe dopadla segmentace

s parametrem $p = 0.5$, a to s chybovostí 1.194%. Nejlepší výsledek segmentace s využitím Minkowského vzdálenosti pro obraz 13a lze vidět na obrázku 13b. Nejhoršího výsledku bylo dosaženo s parametrem $p = 4$, kde výsledná chybovost byla 21.824%. Se zvětšujícím se šumem se chybovost segmentace zvyšuje. Výsledky segmentace při použití Minkowského vzdálenosti pro obraz 13e se nachází v tabulce 4b. Nejnížší chybovosti segmentace bylo dosaženo s hodnotou parametru $p = 0.5$. Chybovost této segmentace byla pouze 1.194%. Nejlepší výsledek segmentace s využitím Minkowského vzdálenosti pro obraz 13e lze vidět na obrázku 13f. V nejhorším případě byla výsledná chybovost segmentace 47.719% s hodnotou parametru $p = 4$. Při segmentaci obrazu s využitím Minkowského vzdálenosti se po zvýšení hodnoty parametru p sníží důležitost velikosti jasu jednotlivých pixelů a daleko více záleží pouze na umístění seedů.

Tabulka 5: V tabulce 5a se nachází výsledky segmentace s využitím geodetické vzdálenosti pro obraz 12a a v tabulce 5b se nachází výsledky segmentace s využitím geodetické vzdálenosti nad obrazem 12e. Parametr ω značí odchylku gaussovského šumu a parametr σ mění hodnotu hrany v grafu podle vzorce uvedeném v kapitole 4.3. Jednotlivé hodnoty určují průměrnou chybovost segmentace s využitím geodetické vzdálenosti.

(a)

ω	$\sigma = 0.1$	$\sigma = 0.2$	$\sigma = 0.3$	$\sigma = 0.4$	$\sigma = 0.5$	$\sigma = 0.6$	$\sigma = 0.7$	$\sigma = 0.8$	$\sigma = 0.9$	čas (s)
0.1	12.609	0.63	0.007	0.002	0.002	0.0004	0.002	0.001	0.006	0.124
0.2	16.995	11.622	10.831	10.369	10.331	10.252	10.196	10.184	10.264	0.122
0.3	18.949	17.837	17.253	17.222	17.352	17.3055	17.412	17.335	17.395	0.129
0.4	20.296	19.826	19.964	19.763	19.752	19.756	19.527	19.539	19.709	0.120
0.5	21.170	20.833	20.688	20.810	20.792	20.852	20.827	20.803	20.899	0.129

(b)

ω	$\sigma = 0.1$	$\sigma = 0.2$	$\sigma = 0.3$	$\sigma = 0.4$	$\sigma = 0.5$	$\sigma = 0.6$	$\sigma = 0.7$	$\sigma = 0.8$	$\sigma = 0.9$	čas (s)
0.1	19.232	5.002	0.499	0.134	0.089	0.061	0.041	0.034	0.041	0.125
0.2	23.412	18.766	18.056	17.618	17.603	17.549	17.596	17.449	17.659	0.129
0.3	25.241	23.174	23.122	22.988	22.988	22.988	23.089	23.046	22.784	0.121
0.4	26.192	24.601	24.566	24.693	24.659	24.659	24.395	24.559	24.560	0.125
0.5	26.958	25.393	25.288	25.357	25.151	25.239	25.356	25.186	25.356	0.127

V tabulce 5a se nachází výsledná průměrná chybovost segmentací s využitím geodetické vzdálenosti pro obrázek 13a. Nejhoršího výsledku pro všechny testy, bez ohledu na velikost šumu ω , bylo dosaženo segmentacemi s parametrem $\sigma = 0, 1$. Nejlepší výsledky, při velikosti šumu ω 0.1, 0.2, 0.3 a 0.5 byly dosaženy s hodnotou $\sigma = 0.8$ a při velikosti šumu 0.4 s hodnotou $\sigma = 0.7$. Nejlepší segmentaci s využitím geodetické vzdálenosti nad obrazem 13a lze vidět na obrázku 13c. Výsledky segmentace s využitím geodetické vzdálenosti pro obrázek 13e jsou zapsány v tabulce 5b. Nejpresnější segmentaci s využitím geodetické vzdálenosti nad obrazem 13e lze vidět na obrázku 13g. Segmentace pro obrázek 13a dopadla obecně lépe než pro obrázek 13e a to z důvodu posunu seedů. Zde je možné vidět vliv umístění seedů pro segmentaci s využitím geodetické vzdálenosti. Segmentace s využitím geodetické vzdálenosti je několikanásobně rychlejší než segmentace s využitím Minkowského vzdálenosti.

Tabulka 6: V tabulce 6a se nachází výsledky segmentace s využitím max-arc vzdálenosti pro obraz 13a a v tabulce 6b se nachází výsledky segmentace s využitím max-arc vzdálenosti nad obrazem 13e. Parametr ω značí odchylku gaussovského šumu a parametr σ mění hodnotu hrany v grafu podle vzorce uvedeném v kapitole 4.3. Jednotlivé hodnoty zapsané v tabulce udávají výslednou průměrnou chybovost segmentace s využitím max-arc vzdálenosti.

(a)

ω	$\sigma = 0.1$	$\sigma = 0.2$	$\sigma = 0.3$	$\sigma = 0.4$	$\sigma = 0.5$	$\sigma = 0.6$	$\sigma = 0.7$	$\sigma = 0.8$	$\sigma = 0.9$	čas (s)
0.1	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.144
0.2	1.641	1.522	1.568	1.542	1.542	1.516	1.623	1.558	1.601	0.145
0.3	13.177	13.556	13.316	13.294	12.997	13.393	12.861	13.174	12.258	0.154
0.4	18.943	19.265	19.314	19.281	19.129	19.198	19.496	18.989	19.172	0.152
0.5	20.884	20.905	20.496	20.661	20.868	20.761	20.933	20.761	20.831	0.149

(b)

ω	$\sigma = 0.1$	$\sigma = 0.2$	$\sigma = 0.3$	$\sigma = 0.4$	$\sigma = 0.5$	$\sigma = 0.6$	$\sigma = 0.7$	$\sigma = 0.8$	$\sigma = 0.9$	čas (s)
0.1	0.0002	0.0003	0.0006	0.0003	0.0001	0.0004	0.0003	0.0002	0.0002	0.197
0.2	1.578	1.665	1.626	1.580	1.651	1.488	1.591	1.548	1.513	0.215
0.3	13.797	13.457	13.484	13.891	14.029	14.374	14.341	14.485	14.232	0.195
0.4	22.519	21.512	21.538	21.219	21.854	21.846	22.024	22.018	22.118	0.205
0.5	23.846	23.324	24.374	23.562	23.881	23.168	23.811	24.277	24.844	0.210

Výsledná chybovost testů segmentace s využitím max-arc vzdálenosti nad obrazem 13a je zapsána v tabulce 6a. Podle tabulek 6a a 6b s výsledky segmentace, která využívá max-arc vzdálenost lze vidět menší závislost na umístění jednotlivých seedů. Tato zmenšená závislost na umístění seedů je dána tím, že se v případě max-arc vzdálenosti nebere v úvahu celá cesta mezi dvěma body, ale pouze největší hrana, tudíž se nebere v úvahu ani vzdálenost mezi dvěma body. Problém segmentace s využitím max-arc vzdálenosti nastává v případě, kdy se vyskytuje největší hrana mimo požadovaný region obrazu. Tato skutečnost lze pozorovat na vyšší chybovosti segmentace při vyšším šumu. Výsledky pro obrázky 13a a 13e jsou téměř identické. Nejpresnější segmentaci s využitím max-arc vzdálenosti nad obrazem 13a lze vidět na obrázku 13d a nejpresnější segmentaci nad obrazem 13e lze vidět na obrázku 13h.

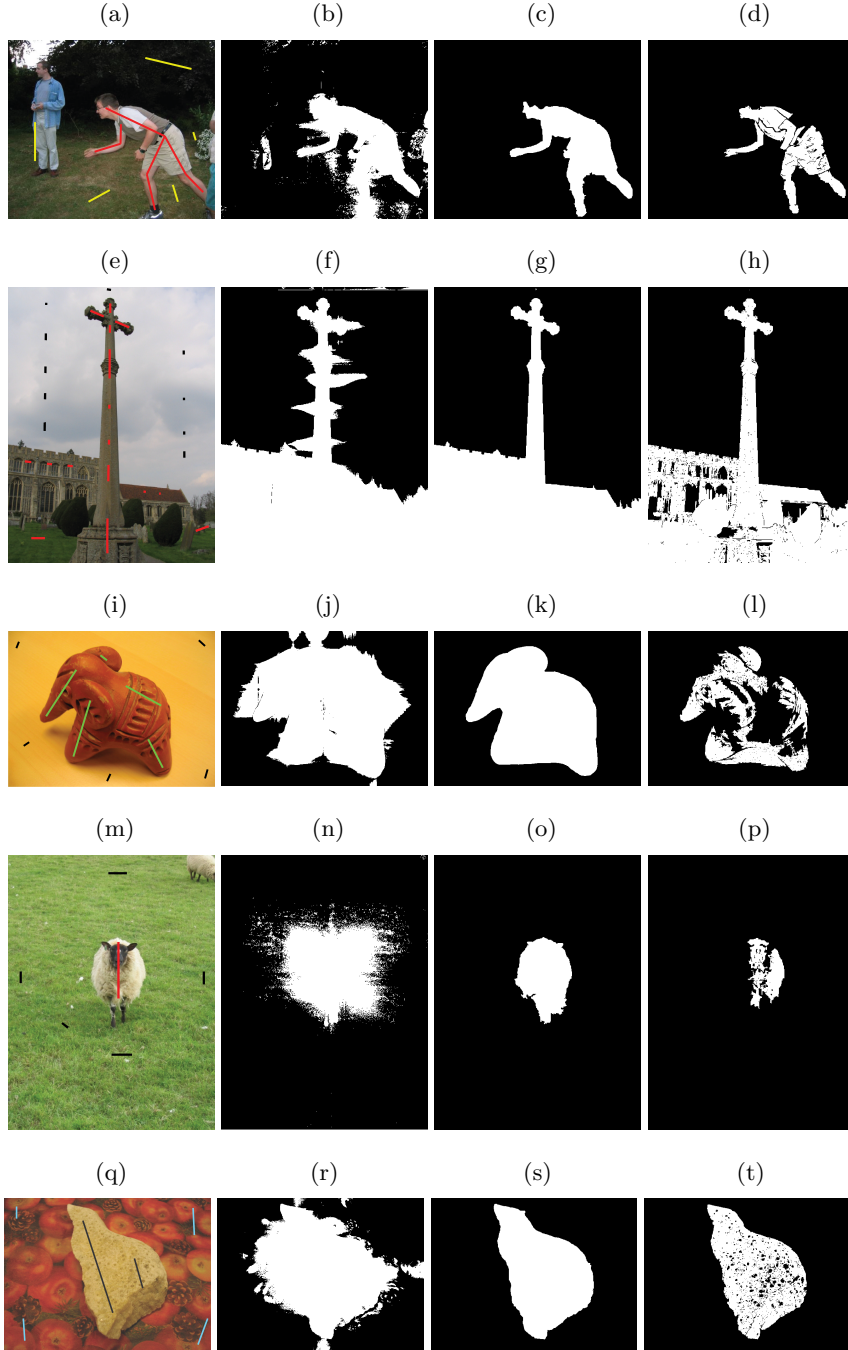
5.2 Reálné obrázky

V této kapitole se nachází testování a porovnání výsledků segmentace s využitím vzdálenosti na reálných obrázcích. Z důvodu většího počtu testů jsou ukázány pouze obrázky nejlepších výsledků pro každou segmentační techniku. Reálné obrazy se od uměle vytvořených liší převážně ve velikosti hrany při přechodu mezi objekty a pozadím. Umělé obrázky jsou vytvořeny tak, aby hrana mezi objektem a pozadím byla skoková, zatímco v reálných obrázcích je převážně hrana postupná. Pro každý testovací obrázek byla testována segmentace s využitím Minkowského vzdálenosti, geodetické vzdálenosti a max-arc vzdálenosti.

Na obrázku 14 jsou jednotlivé testovací obrazy s vyznačenými seedy a výsledné segmentované obrazy pro segmentaci s využitím Minkowského, geodetické a max-arc vzdálenosti. V prvním

Obrázek 14: Reálné obrázky

V prvním sloupci se nachází originální testovací obrázky s vyznačenými seedy, které definují objekt a pozadí. Ve druhém sloupci se nachází nejpřesnější segmentované obrázky s využitím Minkowského vzdálenosti. V předposledním sloupci jsou nejpřesnější segmentované obrázky s využitím geodetické vzdálenosti a v posledním sloupci se nachází segmentované obrázky s využitím max-arc vzdálenosti.



sloupci se nachází originální testovací obrázky s vyznačenými seedy, které definují objekt a pozadí. Ve druhém sloupci se nachází nejpřesnější segmentované obrazy s využitím Minkowského vzdálenosti. V předposledním sloupci jsou nejpřesnější segmentované obrazy s využitím geodetické vzdálenosti a v posledním sloupci se nachází nejpřesnější segmentované obrazy s využitím max-arc vzdálenosti. Rozdílnost barev jednotlivých seedů je pouze z důvodu lepší viditelnosti. Na obrázku 14a, jako objekt označují seedy s červenou barvou a jako pozadí seedy se žlutou barvou. Pro obrázek 14e a 14m označují objekt červené seedy a pozadí černé seedy. U obrázku 14i je objekt označen zelenými seedy a pozadí černými seedy. A na posledním obrázku 14q je objekt označen černými seedy a pozadí světlě modrými seedy.

Tabulka 7: V tabulce 7 se nachází výsledky segmentace s využitím Minkowského vzdálenosti pro všechny testy nad reálnými obrazy (obrázek 14). Parametr p udává hodnotu v Minkowského vzdálenosti. Jednotlivé výsledné hodnoty v tabulce udávají chybovost segmentace s využitím Minkowského vzdálenosti.

obrázek	14a	14e	14i	14m	14q
p=0.5	7.12	6.02	16.73	10.51	14.31
p=1	8.11	6.918	18.36	11.81	18.96
p=2	16.74	9.91	22.54	12.144	24.89
p=4	16.74	12.49	26.91	11.891	27.02
velikost	520x450	450x600	640x480	450x600	640x480
čas (s)	11.641	8.217	9.495	4.82	11.74

Segmentace obrazu s využitím Minkowského vzdálenosti je nejméně přesnou možností ze všech testovaných metrik v této práci. V tabulce 7 se nachází výsledná chybovost segmentace pro všechny reálné obrazy (obrázek 14). Chybovost segmentace se i v reálných obrázcích počítá, jako odchylka výsledného segmentovaného obrazu od ideální předpřipravené masky, která přesně rozděluje obraz na požadovaný objekt a pozadí. Při porovnání vykonaných testů lze vidět, že segmentace s využitím Minkowského vzdálenosti je časově nejnáročnější.

Ve všech testovacích případech lze vidět velkou závislost výsledku segmentace na fyzickém umístění seedů. Čím více seedů umístěných okolo objektu, tím je výsledek segmentace přesnější. Nejlepší výsledky segmentace s využitím Minkowského vzdálenosti jsem získal s parametrem $p = 0.5$, kdy má velikost jasu jednotlivých pixelů značnou váhu ve výpočtu při rozhodování, ve které části se pixel nachází (objekt nebo pozadí). Při postupném zvyšování parametru p se zvětšuje důležitost umístění jednotlivých pixelů nad jejich jasnem. Nejhoršího výsledku jsem dosáhl vždy s parametrem $p = 4$. Nejpřesnější segmentace obrazu s využitím Minkowského vzdálenosti nad obrazem 14a se nachází na obrázku 14b, nad obrazem 14e se nachází na obrázku 14f, nad obrazem 14i se nachází na obrázku 14j, nad obrazem 14m se nachází na obrázku 14n a nad obrazem 14q se nachází na obrázku 14r.

Segmentace s využitím Minkowského vzdálenosti je časově závislá na velikosti obrázku, počtu seedů a velikosti jednotlivých seedů. Tuto skutečnost lze pozorovat z obrázku 14a, kde segmentace trvala 11.641s, zatímco segmentace obrázku 14m, který má více obrazových bodů než obrázek 14a, trvala 8,217s. A to z důvodu menšího součtu obrazových bodů všech seedů.

Hlavním důvodem, proč jsou výsledky segmentace na obrázcích 14n a 14r velmi nepřesné, je malý rozdíl hodnot jednotlivých hran v grafu po převedení obrazu do šedotónu (kapitola 4.2). Jelikož při segmentaci s využitím Minkowského vzdálenosti se prochází jednotlivé obrazové body a porovnávají se přímo s obrazovými body jednotlivých seedů, váha hran při přechodu mezi objektem a pozadím se nebere v potaz. Ze stejného důvodu dopadla segmentace obrazu 14e, která se nachází na obrázku 14f daleko lépe.

Tabulka 8: V tabulce 8a se nachází výsledky segmentace s využitím geodetické vzdálenosti pro všechny testované reálné obrazy bez aplikace Gaussova rozostření. V tabulce 8b se nachází výsledky segmentace s využitím geodetické vzdálenosti nad všemi reálnými obrazy s aplikací Gaussova rozostření. Parametr σ mění hodnotu hrany v grafu podle vzorce uvedeném v kapitole 4.3. Jednotlivé hodnoty určují průměrnou chybovost segmentace s využitím geodetické vzdálenosti.

(a)						(b)					
obrázek	14a	14e	14i	14m	14q	obrázek	14a	14e	14i	14m	14q
$\sigma = 0.1$	4.409	1.548	4.079	9.606	3.618	$\sigma = 0.1$	2.408	1.469	3.975	1.307	0.884
$\sigma = 0.3$	4.370	1.547	4.079	9.468	3.572	$\sigma = 0.3$	2.356	1.469	3.975	9.468	0.879
$\sigma = 0.5$	4.364	1.547	4.079	9.459	3.568	$\sigma = 0.5$	2.353	1.468	3.974	9.459	0.879
$\sigma = 0.7$	4.364	1.547	4.079	9.459	3.568	$\sigma = 0.7$	2.353	1.468	3.974	9.459	0.879
$\sigma = 0.9$	4.364	1.547	4.079	9.459	3.568	$\sigma = 0.9$	2.353	1.468	3.974	9.459	0.879
čas (s)	0.344	0.339	0.337	0.386	0.564	čas (s)	0.342	0.334	0.339	0.385	0.540

Segmentace obrazu s využitím geodetické vzdálenosti dosáhla ve všech testech na reálných obrázcích nejlepších výsledků, tzn. její chybovost byla nejnižší. Pouze pouhým pohledem lze vidět výrazně přesnější segmentaci obrazu s využitím geodetické vzdálenosti než s využitím Minkowského vzdálenosti. Umístění jednotlivých seedů je také velmi důležité. Jelikož se při určování pixelu, jestli se jedná o objekt nebo o pozadí, prochází hrany grafu vytvořeného z originálního obrazu a hledá se nejkratší cesta do jednoho ze seedů. Výsledky segmentací jednotlivých testovacích obrazů, které se nachází na obrázku 14 s použitím Gaussova filtru, jsou zapsány v tabulce 8a a výsledky bez použití Gaussova filtru, jsou zapsány v tabulce 8b.

Podle všech provedených testů je rychlost segmentace s využitím geodetické vzdálenosti několikanásobně vyšší než rychlost segmentace s využitím Minkowského vzdálenosti. Hlavním důvodem je možnost označit všechny seedy definující objekt jako zdrojové vrcholy pro vyhledání nejkratších vzdáleností do všech ostatních vrcholů. Tento postup se provede ještě jednou analogicky pro seedy definující pozadí a poté se pouze porovná, jestli je pixel blíže objektovým seedům nebo seedům označujícím pozadí. Naopak při segmentaci s využitím Minkowského vzdálenosti se prochází každý pixel a porovnává se s každým seedovým pixelem.

Nejlepších výsledků segmentace s využitím geodetické vzdálenosti jsem dosáhl stejně jako v případě umělých obrázků s hodnotou σ v intervalu od 0.5 do 0.9. V případě reálných obrázků byly hrany v grafu již tak nízké, že zvyšování σ od hodnoty $\sigma > 0.5$ již nemělo na výsledek žádný vliv. Aplikací Gaussova filtru se zlepšily výsledky segmentace s využitím geodetické vzdálenosti

ve všech testovacích případech. Jelikož na reálných obrázcích není použit uměle vytvořený šum, tak zlepšení výsledků není tak drastické. Zlepšení přesnosti segmentace aplikací Gaussova filtru bylo v nejlepším případě o cca 3%, bez jakéhokoliv nárůstu času potřebného pro segmentaci.

Tabulka 9: V tabulce 9a se nachází výsledky segmentace s využitím max-arc vzdálenosti pro všechny testované reálné obrazy bez aplikace Gaussova rozostření. V tabulce 9b se nachází výsledky segmentace s využitím max-arc vzdálenosti nad všemi reálnými obrazy s aplikací Gaussova rozostření. Parametr σ mění hodnotu hrany v grafu podle vzorce uvedeném v kapitole 4.3. Jednotlivé výsledné hodnoty určují průměrnou chybovost segmentace s využitím max-arc vzdálenosti.

(a) Bez použití gaussova filtru						(b) S použitím gaussova filtru					
obrázek	14a	14e	14i	14m	14q	obrázek	14a	14e	14i	14m	14q
$\sigma = 0.1$	5.948	9.303	20.230	3.273	3.554	$\sigma = 0.1$	4.799	18.731	22.685	3.281	0.488
$\sigma = 0.1$	5.948	9.303	20.230	3.273	3.554	$\sigma = 0.5$	4.799	18.731	22.685	3.281	0.488
$\sigma = 0.1$	5.948	9.303	20.230	3.273	3.554	$\sigma = 0.9$	4.799	18.731	22.685	3.281	0.488
čas (s)	0.344	0.339	0.337	0.378	0.454	čas (s)	0.342	0.293	0.321	0.367	0.419

Segmentace obrazu s využitím max-arc vzdálenosti na reálných testovacích obrazech byla přesnější než segmentace s využitím Minkowského vzdálenosti, ale méně přesná než segmentace s využitím geodetické vzdálenosti. Tato segmentační technika je velmi závislá na výrazných hranách objektu. Hlavním důvodem je způsob porovnávání, jestli pixel je součástí objektu nebo pozadí. Vzdálenost pixelu k jednotlivým seedům je nejmenší maximální hrana na cestě v grafu ze zdrojového pixelu k seedu. Ze stejného důvodu aplikace Gaussova filtru v některých případech zmenší chybovost segmentace a v některých případech chybovost zvýší. V mých testech pomohla aplikace Gaussova filtru pouze u testovacího obrazu 14a, ve všech ostatních testech aplikace Gaussova filtru zvětšila výslednou chybovost segmentace. Chybovost jednotlivých výsledků segmentace s využitím max-arc vzdálenosti na reálných obrazech, které se nachází na obrázku 14, je zapsána v tabulce 9a. Výsledky segmentace s použitím Gaussova filtru jsou zapsány v tabulce 9b. Z tabulky 9a vyplývá, že změna hodnoty σ nemá žádný vliv na výsledek segmentace.

Segmentace obrazu s využitím max-arc vzdálenosti je u reálných obrazech několikanásobně rychlejší než segmentace s využitím Minkowského vzdálenosti a téměř časově stejně náročná jako segmentace s využitím geodetické vzdálenosti. Nejpresnější segmentace obrazu s využitím max-arc vzdálenosti nad obrazem 14a se nachází na obrázku 14d, nad obrazem 14e se nachází na obrázku 14h, nad obrazem 14i se nachází na obrázku 14l, nad obrazem 14m se nachází na obrázku 14p a nad obrazem 14q se nachází na obrázku 14t.

6 Závěr

Cílem této práce bylo seznámení s problematikou segmentace obrazu s důrazem na segmentaci obrazu s využitím měření vzdálenosti, implementace segmentace obrazu s využitím Minkowského vzdálenosti, geodetické vzdálenosti, max-arc vzdálenosti a následné testování a porovnání výsledků jednotlivých segmentačních technik.

V experimentální části byly provedeny testy na vliv změny σ , která podle vzorečku v kapitole 4.3 mění váhu hrany v grafu při použití segmentace obrazu s využitím geodetické nebo max-arc vzdálenosti. Dále byl zkoumán vliv Gaussova filtru na výsledky segmentace nad reálnými obrazy. Experimenty byly provedeny na reálných obrazech a uměle vytvořených obrazech v grafickém editoru. Na uměle vytvořených obrazech se nachází výrazné hrany mezi objekty a pozadím. V případě obrazů vytvořených v grafickém editoru se navíc přidával šum o různých velikostech ω .

Podle dosažených výsledků je pro segmentaci obrazu s využitím měření vzdálenosti nejméně vhodné použít Minkowského vzdálenost. Minkowského vzdálenost klade příliš veliký důraz na fyzické umístění obrazových bodů, tím je na mysli jejich x-ové a y-ové souřadnice, které na větších obrázcích zastiňují význam jejich jasu. Při testování Minkowského vzdálenosti bylo v drtivé většině případů nejvhodnější použít parametr $p = 0.5$, protože hodnota $p = 0.5$ klade menší důraz na umístění jednotlivých pixelů a přidává na důležitosti rozdílů jasu mezi dvěma body. V provedených testech jsem zjistil, že čím větší je hodnota p , tím je segmentace s využitím Minkowského vzdálenosti méně přesná, kromě ojedinělých případů, kde jednotlivé seedy jsou symetrické a zároveň i jednotlivé objekty a pozadí jsou rozděleny symetricky, například obrázek 12a.

Naopak nejvíce vhodná metrika pro segmentaci využívající měření vzdálenosti je geodetická vzdálenost. V drtivé většině testů byla tato metrika nejpresnější, zvláště na reálných obrázcích. Při testech na umělých obrázcích vychází jako nejvhodnější hodnota $\sigma \in \{0.7, 0.8, 0.9\}$, tuto skutečnost nevyvrací ani testy na reálných obrázcích, kde byla neoptimálnější hodnota $\sigma \in \{0.5, 0.7, 0.9\}$. Při $\sigma \geq 0.4$ byly hodnoty hran v grafu tak nízké, že další zvyšování hodnoty σ nemělo vliv na výsledek segmentace. Jeden z nejdůležitějších aspektů pro dosažení co nejlepších výsledků segmentace s využitím geodetické vzdálenosti je správné umístění seedů. Geodetická vzdálenost, stejně jako Minkowského vzdálenost, je náchylná na fyzické umístění jednotlivých seedů. Vliv použití Gaussova filtru při použití geodetické vzdálenosti je velmi kladný. Gaussův filtr se používá hlavně na potlačení šumu a omezení počtu méně významných hran.

Výsledky segmentace s využitím max-arc vzdálenosti byly přesnější než výsledky segmentace s využitím Minkowského vzdálenosti, ale zároveň méně přesné než výsledky segmentace s využitím geodetické vzdálenosti. Změna hodnoty σ neměla na max-arc vzdálenost žádný vliv, jelikož se počítá s nejvyšší vahou v cestě. Pokud například hrana h má při použití $\sigma = 0.1$ váhu $h_w = 1$ je výsledek segmentace ekvivalentní situaci, kdy hrana h má při použití $\sigma = 0.9$ váhu $h_w = 0.1$. Využití max-arc vzdálenosti má jednu nespornou výhodu, tato vzdálenost je na rozdíl

od geodetické vzdálenosti mnohem více robustní, tím je na mysli, že poloha seedu (v případě, že je seed správně umístěn v objektu a nezasahuje do pozadí nebo naopak) nemá tak důležitou roli. Tato robustnost je dána tím, že se v případě max-arc vzdálenosti nebere v úvahu celá cesta mezi dvěma body, ale pouze největší hrana, tudíž se nebere v úvahu ani vzdálenost mezi dvěma body. Například výsledky segmentace s využitím max-arc vzdálenosti pro obrázek 12a a 12e mají velmi podobné hodnoty. Vliv gaussova filtru na segmentaci s využitím max-arc vzdálenosti není vždy kladný, protože max-arc vzdálenost má nejlepší využití v obrazech s výraznými hranami. Aplikace Gaussova rozostření může v některých případech tyto hrany rozmazat a tím zmenšit přesnost segmentace.

Literatura

- [1] Obrazové segmentační techniky: Přehled existujících metod. Brno, 2005. [online citace 30.4.2018] Dostupné z URL: <http://www.fit.vutbr.cz/~spanel/segmentace/>
- [2] DOUGHERTY G.: Digital Image Processing for Medical Applications. 1. vydání CUP 2009. 462 s. ISBN 978-0-521-86085-7.
- [3] Josef Kolář: Teoretická informatika. Praha, 2000. ISBN 80-900853-8-5.
- [4] Obecné informace o OpenCV knihovně. [online citace 30.4.2018] Dostupné z URL: https://is.mendelu.cz/eknihovna/opory/zobraz_cast.pl?cast=25212
- [5] Jarosla Firt, Rade Holota: Digitalizace a zpracování obrazu. [online citace 30.4.2018] Dostupné z URL: <http://home.zcu.cz/~holota5/publ/DigZprO.pdf>
- [6] Monisha, S., Malathi, K., Monika, S. (2016). Implementation of face detection using edge detection and thresholding. Research Journal of Pharmaceutical, Biological and Chemical Sciences, 7, 160-166.
- [7] Mokhtarian, F., Suomela, R. (1998). Robust image corner detection through curvature scale space. IEEE Transactions on Pattern Analysis and Machine Intelligence, 20(12), 1376-1381.
- [8] Rodriguez, A. A., Mitchell, O. R. (1991). Image segmentation by successive background extraction. Pattern Recognition, 24(5), 409-420.
- [9] Roerdink, J. B. T. M., Meijster, A. (2000). The watershed transform: Definitions, algorithms and parallelization strategies. Fundamenta Informaticae, 41(1-2), 187-228.
- [10] Illingworth, J., Kittler, J. (1988). A survey of the hough transform. Computer Vision, Graphics and Image Processing, 44(1), 87-116.
- [11] Chan, T. F., Vese, L. A. (2001). Active contours without edges. IEEE Transactions on Image Processing, 10(2), 266-277.
- [12] Li, C., Xu, C., Gui, C., Fox, M. D. (2005). Level set evolution without re-initialization: A new variational formulation. Prezentováno na IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR 2005, , I 430-436.
- [13] Carr, H., Snoeyink, J., Van Panne, M. D. (2004). Simplifying flexible isosurfaces using local geometric measures. Prezentováno na IEEE Visualization 2004, VIS 2004, 497-504.
- [14] T. F. Cootes and C. J. Taylor: Constrained Active Appearance Models. Dept. Imaging Science and Biomedical Engineering, University of Manchester, Manchester M13 9PT U.K. [online citace 30.4.2018] Dostupné z URL: <http://www.ai.mit.edu/courses/6.899/papers/cootesTaylor.pdf>

- [15] Argyle E.: Techniques for Edge Detection, Proc. IEEE, 59, 2, February 1971, 285-287.
- [16] P. Kanungo, P. K. Nanda and U. C. Samal : Image Segmentation Using Thresholding and Genetic Algorithm, Image Processing and Computer Vision Lab. Department of Electrical Engineering National Institute of Technology, Rourkela, 69008. Dostpné z URL: https://www.researchgate.net/publication/37676411_Image_Segmentation_Using_Thresholding_and_Genetic_Algorithm
- [17] Nameirakpam Dhanachandra, Khumanthem Manglem, Yambem JinaChanu: Image Segmentation Using K -means Clustering Algorithm and Subtractive Clustering Algorithm. National Institute of Technology, Manipur 795 001, India.
- [18] Deza, Elena; Deza, Michel Marie: Encyclopedia of Distances. ISBN 978-3-642-00234-2.
- [19] George Economou, Vassilios Pothos and Apostolos Ifantis: GEODESIC DISTANCE AND MST BASED IMAGE SEGMENTATION. Electronics Laboratory, Department of Physics, University of Patras, GR-26500 Patras, Greece 2004.
- [20] Wikipedia: Thresholding (image processing). [online citace 30.4.2018] Dostupné z URL: [https://en.wikipedia.org/wiki/Thresholding_\(image_processing\)](https://en.wikipedia.org/wiki/Thresholding_(image_processing))
- [21] Wikipedia: Canny edge detector. [online citace 30.4.2018] Dostupné z URL: https://en.wikipedia.org/wiki/Canny_edge_detector
- [22] Wikipedia: Canny edge detector. [online citace 30.4.2018] Dostupné z URL: https://en.wikipedia.org/wiki/Minkowski_distance
- [23] Adams, R., Bischof, L. (1994). Seeded region growing. IEEE Transactions on Pattern Analysis and Machine Intelligence, 16(6), 641-647.
- [24] Clark, M. C., Hall, L. O., Goldgof, D. B., Velthuisen, R., Reed Murtagh, F., Silbiger, M. S. (1998). Automatic tumor segmentation using knowledge-based techniques. IEEE Transactions on Medical Imaging, 17(2), 187-201.
- [25] Haralick, R. M., Shapiro, L. G. (1985). Image segmentation techniques. Computer Vision, Graphics, & Image Processing, 29(1), 100-132.